

УДК 004.9

С. Г. Антощук, д-р техн. наук,
В. А. Емельянов, канд. техн. наук

МЕТОД НЕЙРОСЕТЕВОГО ПРОГНОЗИРОВАНИЯ ИЗМЕНЕНИЯ СОСТОЯНИЯ ОБЪЕКТОВ ДИАГНОСТИКИ НА МЕТАЛЛУРГИЧЕСКОМ ПРОИЗВОДСТВЕ

Аннотация. Реализован метод анализа временных рядов основных параметров объектов диагностики металлургического предприятия, основанный на нейросетевом прогнозировании состояния этих объектов. Описана и обоснована структура нейронной сети для прогнозирования изменения основных параметров передвигающихся миксеров на металлургическом производстве. Проведенное сравнение различных методов для прогнозирования состояния передвигающихся миксеров показало лучшую эффективность при нейросетевом прогнозировании.

Ключевые слова: нейронная сеть, многослойный перцептрон, алгоритм обучения, временной ряд, прогнозирование, метод наименьших квадратов, экспоненциальное сглаживание, метод скользящего среднего, техническая диагностика, передвижной миксер, металлургическое предприятие

S. Antoshchuk, ScD.,
V. Iemelianov, PhD.

THE NEURAL NETWORK PREDICTING METHOD FOR OBJECT'S CONDITION DIAGNOSING ON THE METALLURGICAL ENTERPRISE

Abstract. Diagnostic object basic parameters time series analysis method of metallurgical enterprises realized and based on neural network prediction of this objects. The neural network structure for basic parameters of the moving mixers condition prediction has been described. Different methods comparison proved better efficacy prediction in case of neural network forecast background.

Keywords: neural network, multilayer perception, learning algorithm, time series, prediction, least squares method, exponential smoothing, moving average method, technical diagnostics, moving mixer, metallurgical enterprises

С. Г. Антощук, д-р техн. наук,
В. О. Емельянов, канд. техн. наук

МЕТОД НЕЙРОМЕРЕЖНОГО ПРОГНОЗУВАННЯ ЗМІН СТАНУ ОБ'ЄКТІВ ДІАГНОСТИКИ НА МЕТАЛУРГІЙНОМУ ВИРОБНИЦТВІ

Анотація. Реалізовано підхід до аналізу часових рядів основних параметрів об'єктів діагностики металургійного підприємства, заснований на нейромережному прогнозуванні стану цих об'єктів. Описано та обґрунтовано структуру нейронної мережі для прогнозування зміни основних параметрів рухомих миксерів на металургійному виробництві. Проведене порівняння різних методів для прогнозування стану рухомих миксерів показало кращу ефективність прогнозування при нейромережевому прогнозуванні.

Ключові слова: нейронна мережа, багатосаровий перцептрон, алгоритм навчання, часовий ряд, прогнозування, метод найменших квадратів, експоненціальне згладжування, метод ковзального середнього, технічна діагностика, рухомий миксер, металургійне підприємство.

Введение. Постановка задачи

Современное металлургическое производство характеризуется повышением требований к безотказности критического производственного оборудования и снижением затрат на проведение ремонтов и устранение последствий аварийных ситуаций [1, 2].

На металлургическом производстве таким оборудованием являются передвижные миксеры, чугуновозы, ковши, доменные печи и др. Это оборудование (объекты) представляет собой отдельную группу для диагностики и определения опасности рисков,

связанных с ресурсом работы содержащегося в них огнеупорного компонента – футеровки. Последняя предотвращает нагрев и разрушение корпусов соответствующего оборудования под воздействием высоких температур (свыше 1000 °С) находящегося в нем жидкого чугуна.

Таким образом, деградация и разрушение футеровки приводит к разрушениям оборудования, т.е. к аварийным ситуациям и, следовательно, к увеличению затрат на проведение ремонтных работ и возникновению простоев, связанным с ними.

Поэтому своевременный мониторинг, диагностика и прогнозирование состояния

© Антощук С.Г., Емельянов В.А., 2014

футеровки с целью определения ее ресурса является важной задачей, которая решается в данной статье.

Диагностика состояния футеровки производится разными способами: на основе анализа температуры корпуса оборудования; по заданному временному интервалу ее использования и наиболее точный метод – определение коэффициента износа футеровки, на основании значений которого принимается решение о ремонте оборудования сопровождающегося полной или частичной заменой футеровки в зависимости от количества поврежденных ее участков.

Анализ отечественных и зарубежных источников литературы [1–5] показал, что в настоящее время осуществляются попытки создания методов и средств оценки состояния описываемой группы оборудования, содержащего футеровку, но вопросы прогнозирования изменения его состояния в полной мере еще не рассматривались. Следовательно, проводимые исследования являются актуальными.

Выбор метода прогнозирования изменения состояния объектов диагностики

В качестве объекта диагностирования (ОД) металлургического производства исследуются передвижные миксеры типа ПМ 350 т, которые используются для перевозки жидкого чугуна. Данный объект содержит описанный выше огнеупорный компонент – футеровку.

Диагностику группы оборудования, содержащего футеровку, на металлургическом предприятии можно осуществить на основе анализа временных рядов ключевых параметров ОД, например, коэффициент износа футеровки ОД и др.

Таким образом, прогнозируемый параметр ОД представляет собой временной ряд, у которого последние N отсчетов принимают такой вид:

$$Y(t - N + 1), Y(t - N + 2), \dots, Y(t), \quad (1)$$

где Y – вектор диагностируемых свойств объекта, t – дискретное время.

Тогда прогнозирование свойств ОД сводится к построению некоторой модели, позволяющей найти значение вектора Y в

следующий момент времени $t + 1$ по предшествующим значениям N временного ряда, т.е.

$$Y(t + 1) = f[Y(t), Y(t - 1), \dots, Y(t - N + 1)], \quad (2)$$

где f – нелинейная вектор-функция, которую необходимо оценить.

При этом точность прогноза можно оценить, используя, например, манхэттенское расстояние

$$\|\varepsilon\| = \sum_{t=2}^{N-1} \|Y'_{t+1} - Y_{t+1}\|, \quad (3)$$

где Y'_{t+1} – прогнозируемое значение свойства ОД, определенное для момента времени $t + 1$, Y_{t+1} – реальное значение вектора Y для момента времени $t + 1$, ε_{t+1} – ошибка прогнозирования.

В настоящее время известен ряд методов прогнозирования [6, 7]:

- эвристические методы;
- математические методы временной экстраполяции;
- математические методы пространственной экстраполяции;
- методы моделирования процессов развития;
- логические и структурные методы.

К недостаткам перечисленных выше методов следует отнести: малую робастность в условиях шумов; неспособность выдавать многопараметрический прогноз; сложность обработки данных, представленных в разнотипных шкалах и т.д.

В последние годы появилось значительное количество публикаций по применению нейронных сетей для решения задачи прогноза [7–9]. Возможность использования нейронных сетей (НС) в прогнозировании временных рядов основывается на теореме об универсальной аппроксимации, которая утверждает, что многослойного персептрона с одним скрытым слоем достаточно для построения равномерной аппроксимации с точностью ε для любого обучающего множества, представленного набором входов (x_1, x_2, \dots, x_n) и желаемых откликов $f(x_1, x_2, \dots, x_n)$ [10].

Вместе с тем, и сегодня инженерные методики решения задач диагностики объектов на металлургическом производстве, которые могли бы использоваться для таких сложных объектов, как передвижные миксеры, коксовые печи и т.д., не используются. Обычно эти работы ограничиваются лишь общими рекомендациями по использованию тех или иных архитектур нейронных сетей, алгоритмов их обучения и иллюстративными примерами, показывающими возможности НС.

Решение задачи прогнозирования технического состояния ОД на металлургическом производстве в нейросетевом базисе позволяет использовать такие преимущества НС, как:

- способность осуществлять многопараметрический прогноз [7];
- нечувствительность к недостатку априорной и апостериорной информации;
- способность к обобщению и дополнительному обучению;
- робастность по отношению к внешним возмущениям и др.

Сказанное выше убедительно свидетельствует о перспективности постановки и решения задачи прогнозирования технического состояния ОД металлургического производства с помощью НС.

Для прогнозирования изменения состояния передвижных миксеров предложено использовать полносвязную трёхслойную нейронную сеть, в которой каждый нейрон предшествующего слоя имеет связи со всеми нейронами последующего слоя.

Реализация метода нейросетевого прогнозирования для оценки состояния передвижных миксеров ПМ 350 т.

Предлагаемый метод прогнозирования состоит из нескольких основных этапов:

- подготовка исходных данных;
- построение нейросетевой модели;
- обучение нейронной сети;
- собственно прогнозирование (реализация метода).

Реализация данного метода в нейросетевом базисе осуществляется следующим образом:

– выделяется временной интервал (интервал наблюдения), который является обучающей выборкой для НС;

– задается шаг прогноза $T_{прогн}$ с учетом требований к прогнозу (краткосрочный, среднесрочный, долгосрочный прогноз);

– после процесса обучения НС на интервале наблюдения ($T_{набл}$) вычисляются прогнозируемые значения $y_i(t + T_{прогн})$, для этого на вход НС подается значение времени ($t + T_{прогн}$);

– далее процесс прогнозирования повторяется в режиме реального времени.

Подготовка исходных данных предполагает формирование обучающей выборки на основе существующих изменяемых параметров передвижных миксеров (табл. 1). Использовано десять основных параметров:

P_{max} – максимально возможное количество заливок чугуна в миксер по технической документации;

P_{used} – количество произведенных заливок чугуна в миксер;

T_{cur} – температура чугуна, залитого в данный момент времени t ;

T_{avg} – средняя температура чугуна, который перевозит исследуемый миксер;

T_{max} – максимальная температура чугуна, который перевозит исследуемый миксер, согласно технической документации;

T_{mixer} – средняя температура корпуса передвижного миксера;

$T_{mixerMAX}$ – максимально допустимая температура корпуса миксера;

W_{max} – максимально допустимая масса чугуна для перевозки в миксере;

W_{avg} – среднее значение массы чугуна, перевозимого миксером;

W_{cur} – текущее значение массы чугуна, перевозимого миксером;

KF – коэффициент износа футеровки на данный момент времени t .

Исходные данные предварительно нормировались.

1. Фрагмент обучающей выборки

P_{max}	1500	1500	1500	1500	1500	1500	1500	1500
P_{used}	50	60	70	80	90	100	110	120
T_{cur}	1100	1190	1240	1180	1180	1200	1200	1280
T_{avg}	1200	1200	1200	1200	1200	1200	1200	1200
T_{max}	1600	1600	1600	1600	1600	1600	1600	1600
W_{max}	350	350	350	350	350	350	350	350
W_{avg}	300,1	305,2	301,6	301,8	303,4	303,5	305,2	305,6
W_{cur}	298,4	310,2	294,1	299,7	301,8	320,2	310,6	315,7
T_{mixer}	41	41	41	42	44	44	44	44
$T_{mixerMAX}$	90	90	90	90	90	90	90	90
KF	0,1	0,11	0,13	0,14	0,17	0,17	0,18	0,18

Таким образом, используемая в данной работе сеть содержит 11 входных нейронов, 5 нейронов в скрытом слое и 2 выходных нейрона (структура НС имеет вид: 11–5–2).

Число нейронов в скрытом слое (CountN) определено экспериментальным путем (рис. 1). Как показывает анализ найденной зависимости ошибки обучения НС от числа нейронов в скрытом слое, минимальная ошибка обучения (Error) обеспечивается при числе нейронов в скрытом слое, равном 5, и при дальнейшем увеличении количества нейронов в скрытом слое качество работы НС ухудшается, что объясняется эффектом «переобучения».

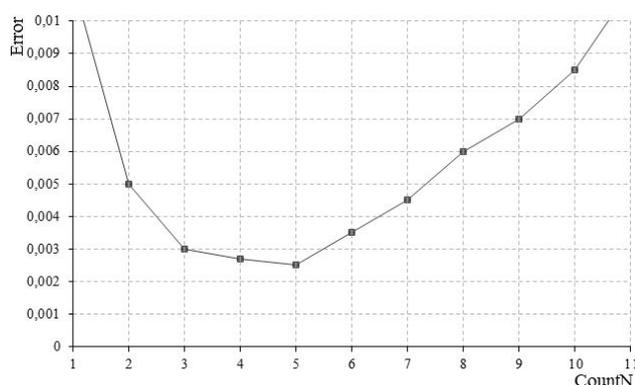


Рис. 1. Зависимость изменения ошибки НС от числа нейронов в скрытом слое

Количество нейронов в выходном слое обусловлено тем, что НС прогнозирует изменение следующих основных параметров – коэффициента износа футеровки KF , на основании которого осуществляется при-

нятие решение о дальнейшей эксплуатации миксеров и количество оставшихся заливок чугуна в миксер – P_{count} .

В работе для предотвращения процесса «переобучения» НС определено рациональное количество эпох обучения – 270. Для обучения нейронной сети используется алгоритм обратного распространения ошибки [10, 11].

Сравнительные результаты нейросетевого и классических методов прогнозирования изменения состояния передвижных миксеров ПМ 350 т.

При оценке эффективности нейросетевого прогнозирования технического состояния передвижных миксеров осуществляется сравнительный анализ с рядом классических методов:

- экспоненциального сглаживания;
- скользящего среднего;
- метода наименьших квадратов.

Прогноз по методу скользящего среднего осуществлялся согласно выражению

$$y_{t+1} = \frac{1}{N} \sum_{b=0}^N y_{t-b+1}, \quad (5)$$

где N – число предшествующих периодов, входящих в скользящее среднее; y_t – фактическое значение в момент времени t ; y_{t+1} – прогнозируемое значение в момент времени $t + 1$.

Для прогноза по методу экспоненциального сглаживания применялось выражение

$$y_{t+1} = y_t + \alpha(A_t - y_t) = \alpha \cdot A_t + (1 - \alpha) \cdot y_t, \quad (6)$$

где y_{t+1} – предсказанное значение параметра KF на основе предыдущего значения y_t , скорректированного с учетом погрешности прогноза ($A_t - y_t$) и весового коэффициента α ($0 < \alpha < 1$).

Прогноз с использованием метода наименьших квадратов проводился для аппроксимирующей функции $f(t)$ в виде полинома четвертого порядка:

$$y = -0,00001x^4 + 0,00044x^3 - 0,0049x^2 + 0,042x + 0,1007. \quad (7)$$

Экспериментальная проверка показала, что дальнейший рост степени полинома практически не приводит к уменьшению погрешности аппроксимации функции $Y = f(t)$.

На рис. 2 приведены результаты сравнительного анализа нейросетевого и классических методов прогнозирования коэффициента износа футеровки миксера – KF , как наиболее значимого параметра.

На рисунке 2:

KF_{real} – реальное значение коэффициента износа футеровки;

KF_{MA} – значение коэффициента износа футеровки, вычисленное на основе метода скользящего среднего;

KF_{ES} – значение коэффициента износа футеровки, вычисленное с использованием метода экспоненциального сглаживания;

KF_{MLS} – значение коэффициента износа футеровки, вычисленное с использованием метода наименьших квадратов;

KF_{NN} – значение коэффициента износа футеровки, вычисленное с использованием НС.

В процессе решения задачи прогнозирования шаг Δt соответствовал: в задаче краткосрочного прогнозирования $\Delta t = 100$ заливок чугуна в миксер; в задаче среднесрочного прогнозирования

$\Delta t = 400$ заливок чугуна в миксер; в задаче долгосрочного прогнозирования $\Delta t = 1000$ заливок чугуна в миксер.

На рис. 2 принято, что момент прогноза равен $t = 300$ заливок чугуна в миксер; интервал $[300;400]$ соответствует краткосрочному прогнозированию; интервал $[300;700]$ – среднесрочному прогнозированию; интервал $[300;1300]$ долгосрочному прогнозированию.

Результаты сравнительного анализа работы классических и нейросетевого методов прогнозирования технического состояния миксера приведены в табл. 2.

В табл. 2 используются следующие обозначения: S – краткосрочный прогноз; M – среднесрочный прогноз; L – долгосрочный прогноз.

Точность прогноза оценивалась по ошибке ε согласно (3) на исходных и на зашумленных данных при отношении сигнал-помеха, равном 20.

Анализ результатов, приведенных в табл. 2, показал, что нейросетевой метод характеризуется ошибкой прогнозирования по крайней мере в два раза меньшей, чем классические методы.

Разработанный нейросетевой метод апробирован на металлургических предприятиях. Анализ результатов прогнозирования коэффициента износа футеровки KF (рис. 2) по измеренным параметрам ОД показал, что при количестве заливок чугуна в миксере с 900 до 1000 заметна устойчивая тенденция к деградации футеровки, о чем свидетельствует превышение параметра KF критического для него значения 0,35. В данном случае результаты прогноза показали, что если количество заливок превысило 900, то необходимо остановить функционирование передвижного миксера и снять его с эксплуатации, хотя согласно технической документации миксер должен еще выдержать 600 заливок жидкого чугуна.

Таким образом, своевременное прогнозирование критического состояния ОД позволит своевременно принять решение о его ремонте, не допустит разрушения миксера из-за перегорания его корпуса под действием высоких температур жидкого чугуна.

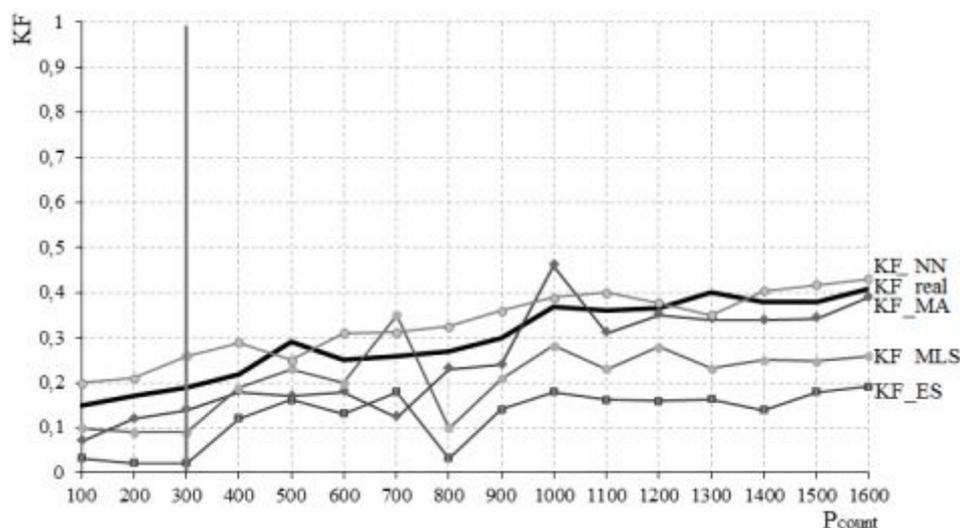


Рис. 2. Результаты прогноза параметра *KF*

2. Результаты прогнозирования изменения параметров передвижного миксера ПМ 350 т

Метод прогнозирования	Ошибка прогноза параметра передвижного миксера (ϵ)					
	Допустимое количество заливок чугуна, P_{count} (%)			Коэффициент износа футеровки, KF (%)		
	<i>S</i>	<i>M</i>	<i>L</i>	<i>S</i>	<i>M</i>	<i>L</i>
Без шума						
1. Метод экспоненциального сглаживания	5,83	5,97	6,6	6,13	6,76	7
2. Метод скользящего среднего	5,69	5,77	5,74	5,83	5,82	5,9
3. Метод наименьших квадратов	5,7	5,9	5,6	5,8	5,8	5,6
4. Нейросетевой метод	1,44	1,51	2,67	1,55	2,87	2,92
С шумом						
1. Метод экспоненциального сглаживания	6,83	7,17	7,73	6,58	6,61	7,27
2. Метод скользящего среднего	7,13	7,15	7,65	7,1	7,13	7,61
3. Метод наименьших квадратов	6,2	6,45	6,65	6,63	6,83	6,5
4. Нейросетевой метод	2,98	3,15	3,23	3,95	3,17	3,42

Выводы

Применение нейросетевого метода позволило обнаруживать критические состояния ОД, то есть выявить количество заливок чугуна, при котором происходит качественное изменение состояния футеровки, что позволило своевременно перевести оборудование в режим ремонта, предотвратить убытки от последствий аварийных ситуаций.

В перспективе предложенный нейросетевой метод может эффективно использоваться для прогнозирования других объектов на металлургическом производстве, например для прогнозирования состояния футеровки коксовой печи или открытых чугуновозов, поскольку данные объекты также содержат футеровку.

Список использованной литературы

1. Суков Г. С. Модернизация и комплексное оснащение современным оборудованием предприятий металлургии / Г. С. Суков, Ю. Н. Белобров, Н. Н. Попов, В. А. Дзержинский // *Металлургия: Тенденции развития*. – 2008. – № 03. – С.4–7.
2. Бигус Г. Техническая диагностика опасных производственных объектов / Г. Бигус, Ю. Даниев. – 2010. – Наука, – 418 с.
3. Czichos H. Handbook of Technical Diagnostics. / H. Czichos. – Springer, 2013. – 566 p
4. Gerasimos R. Intelligent Industrial Systems: Modeling, Automation and Adaptive Behavior / R. Gerasimos. – Industrial Systems Institute & National Technical University of Athens, 2010. – 601 p.

5. Korbicz J. Modeling, Diagnostics and Process Control / J. Korbicz, J.M. Koscielny. – Springer, 2011. – 400 p.

6. Афанасьев В. Н. Анализ временных рядов и прогнозирование. / В. Н. Афанасьев, П. Н. Юзбашев. – М. : Финансы и статистика, 2001. – 288 с.

7. Назаров А. В. Нейросетевые алгоритмы прогнозирования и оптимизации систем. / А. В. Назаров, А. И. Лоскутов – С-Пб.: Наука и техника, 2003. – 384 с.

8. Chen X. A Modified, error Back-propagation Algorithm for Complex-value Neural Networks / X. Chen, Z. Tang, C. Varjappan. // *International Journal of Neural Systems*. – 2005. – Vol. 15(6). – P. 435 – 443.

9. Costarelli D. Multivariate Neural Network Operators with Sigmoidal Activation Functions / D. Costarelli, R. Spigler. // *Neural Networks*. – Vol.48. – 2013. – P. 72 – 77.

10. Haykin S. Neural Networks and Learning Machines (3rd Edition) / S. Haykin. – Prentice Hall, 2008. – 936 p.

11. Suzuki Kenji Artificial Neural Networks: Architectures and Applications [Text] / Kenji Suzuki. – InTech, 2013. – 256 p.

5. Korbicz J., and Koscielny J.M. Modeling, Diagnostics and Process Control, (2011), *Springer Publ.*, 400 p. (In English).

6. Afanasiev V.N., and Iuzbashev P.N. Analiz vremennyh riadov s prognozirovanie [Time Series Analysis and Prediction], (2001), *Finance and Statistics Publ.*, Moscow, Russian Federation, 288 p. (In Russian).

7. Nazarov A.V., and Loskutov A.I. Neirosetevye algoritmy prognozirovaniia i optimizacii system [Neural Network Algorithms of the Prediction and Optimization], (2003), *Science and Thechnics Publ.*, St. Petersburg, Russian Federation, 384 p. (In Russian).

8. Chen X., Tang Z., and Varjappan C. (2005), A Modified, Error Back-propagation Algorithm for Complex-value Neural Networks, *International Journal of Neural Systems Publ.*, Vol. 15(6), pp. 435 – 443 (In English).

9. Costarelli D., and Spigler R., (2013), Multivariate Neural Network Operators with Sigmoidal Activation Functions, *Neural Networks Journal Publ.*, Vol. 48, pp. 72 – 77 (In English).

10. Haykin S. Neural Networks and Learning Machines, (2008), *Prentice Hall Publ.*, 936 p. (In English).

11. Suzuki K. Artificial Neural Networks: Architectures and Applications, (2013), *InTech Publ.*, Winchester, Hampshire, 256 p. (In English).

Получено 15.02.2014

References

1. Sukov S.G., Belobrov Iu.N., Popov N.N. and Dzerginskii V.A. Modernizatciia i kompleksnoe osnashchenie sovremennym oborudovaniem predpriatii metalurgii [Modernization and Integrated with Modern Equipment in Metallurgy], (2008), *Metallurgy: Tendencies of development Publ.*, Vol. 03, pp. 4 – 7 (In Russian).

2. Bigus G. and Daniev Iu. Tehnicheskaia diagnostika opasnyh proizvodstvennyh obektov [Technical Diagnostics of the Dangerous Industrial Objects], (2010), *Science Publ.*, Moscow, Russian Federation, 418 p. (in Russian).

3. Czichos H. Handbook of Technical Diagnostics, (2013), *Springer Publ.*, 566 p. (In English).

4. Gerasimos R. Intelligent Industrial Systems: Modeling, Automation and Adaptive Behavior, (2010), *Industrial Systems Institute & National Technical University of Athens Publ.*, Athens, Greece, 601 p. (In English).



Антощук Светлана Григорьевна,
д.т.н., проф., директор ин-та компьютерных систем Одесского нац. политехнического ун-та.
Тел.: +38048-7058-584,
E-mail: asg@ics.opu.ua



Емельянов Виталий Александрович,
к.т.н., доц. Севастопольского ин-та банковского дела Университета банковского дела Национального банка Украины, ул. Парковая, 6, г. Севастополь, 99057,
Тел. (0692) 53-96-11
E-mail:
v.yemelyanov@gmail.com